

①

# Optimisation et réduction

Optimisation : recherche de la meilleure solution à un problème

Réduction : représentation simplifiée d'une donnée complexe

Exemple typique : réduction de dimension

Données en grande dimension, volonté de les représenter en 2D (eg UMAP, TSNE)

Signaux représentés comme somme de signaux types Fourier

LA QUESTION que cherche-t-on à optimiser?  
Y a-t-il une meilleure façon 'absolue' de trouver la meilleure réponse à une question?  
(Spoilers en général non)

I) Un premier exemple : moindres carrés

1) Ajustement d'une courbe à partir de série temporelle

Cas 1: la droite :

On a des données  $(t_i, y_i)$ , on cherche la meilleure droite :

$y = \alpha t + \beta$   
qui minimise

$$\sum_{i=1}^N (\alpha t_i + \beta - y_i)^2$$

②

On peut déterminer  $\alpha$  et  $\beta$  et rappeler la chose suivante :

$\alpha, \beta \rightarrow \sum (\alpha t_i + \beta - y_i)^2$  est une fonction régulière et au point de minimum on a

$$\frac{\partial}{\partial \alpha} = \frac{\partial}{\partial \beta} = 0$$

$$\frac{\partial}{\partial \alpha} = \sum (\alpha t_i + \beta - y_i) t_i$$

$$\frac{\partial}{\partial \beta} = \sum (\alpha t_i + \beta - y_i)$$

$$\Rightarrow \begin{aligned} \alpha (\sum t_i) + \beta (\sum 1) &= \sum y_i t_i \\ \alpha \sum t_i + \beta (\sum 1) &= \sum y_i \end{aligned}$$

C'est une équation !

$$M \begin{pmatrix} \alpha \\ \beta \end{pmatrix} = \begin{pmatrix} u \\ v \end{pmatrix}$$

On peut généraliser ça aux paraboles

$$\alpha, \beta, \gamma \rightarrow \sum (\gamma t_i^2 + \alpha t_i + \beta - y_i)^2$$

Exercice: décrire la matrice

NB

Com promis à faire entre nombre de données et paramètres.

$N$  points et  $N$  paramètres = relier les points

③

Remarque 1: ce n'est pas tout à fait la distance du nuage de point à la droite.

Remarque 2: interprétation par maximum de vraisemblance

Modèle:  $y = \alpha t + \beta + \underbrace{\epsilon}_{\text{bruit}} \sim \mathcal{N}(0, \sigma^2)$   $\sigma^2$  comme l'erreur de mesure

Densité de probabilité d'observer  $y_i$  au temps  $t_i$  pour des paramètres  $\alpha, \beta$

$$P(t_i, y_i | \alpha, \beta) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(\alpha t_i + \beta - y_i)^2}{2\sigma^2}}$$

$\leftarrow$  normalisation

Proba (densité d'observer toutes les données)

$$L(\alpha, \beta) = P((t_1, y_1), (t_2, y_2), \dots | \alpha, \beta) = \frac{1}{(\sigma^2)^N} \prod_{i=1}^N e^{-\frac{(\alpha t_i + \beta - y_i)^2}{2\sigma^2}}$$

On cherche à maximiser cela i.e. à minimiser  $-\log L(\alpha, \beta)$

$$-\log L(\alpha, \beta) = + N \log(\sigma^2) + \frac{1}{\sigma^2} \sum_{i=1}^N (\alpha t_i + \beta - y_i)^2$$

ind. de  $\alpha, \beta$

$\hookrightarrow -\log L(\alpha, \beta)$  est minimale quand on minimise les moindres carrés.

④

II Projection orthogonale

1) Principe

Rappel:distance euclidienne dans  $\mathbb{R}^d$ 

$$d(x, y) = \sqrt{\sum_{i=1}^d (x_i - y_i)^2}$$

produit scalaire

$$\langle \vec{x}, \vec{y} \rangle = \sum_{i=1}^d x_i y_i$$

on dit que

$$\vec{x} \perp \vec{y} \quad \text{si} \quad \langle \vec{x}, \vec{y} \rangle = 0$$

Espace vectoriel :

$$0 \in F$$

$$\text{Si } u, v \in F$$



$$u + v \in F$$

$$\lambda u \in F$$

(Espace affine) : Espace vectoriel shifté d'un point (" $x_0 + F$ ")Projection orthogonal de  $x$  sur un espace affine ( $y_0 + F$ ) est le point de  $y_0 + F$  :  $x^\perp$ 

$$\text{car } x^\perp \in y_0 + F$$

$$(x - x^\perp) \perp y \quad \forall y \in \underline{F}$$

NB souvent pour simplifier on prendra  $x_0 = 0$ .

⑤

2) Un premier cas : les séries de Fourier

Une première approche consiste à avoir des sous-espaces définies à l'avance

On considère un signal  $T$ -périodique

Idee : Un signal périodique peut être vu comme une somme de sinusoides

$$\begin{array}{l} t \rightarrow \cos\left(2n\pi \frac{t}{T}\right) \\ t \rightarrow \sin\left(2n\pi \frac{t}{T}\right) \end{array} \quad \left| \quad t \rightarrow e^{i2n\pi \frac{t}{T}}\right.$$

version réelle

Etape 1 : En quoi c'est orthogonal ?

Produit scalaire

réel  $\langle f, g \rangle_{\mathbb{R}} = \frac{2}{T} \int_0^T f(s) g(s) ds$

complexe  $\langle f, g \rangle_{\mathbb{C}} = \frac{1}{T} \int_0^T f(s) \overline{g(s)} ds$

Exercice :

$$\frac{2}{T} \int_0^T \cos\left(2n\pi \frac{s}{T}\right) \cos\left(2n'\pi \frac{s}{T}\right) ds = \begin{cases} 0 & \text{si } n \neq n' \\ 1 & \text{si } n = n' \end{cases}$$

$$\frac{2}{T} \int_0^T \sin\left(2n\pi \frac{s}{T}\right) \sin\left(2n'\pi \frac{s}{T}\right) ds = \begin{cases} 0 & \text{si } n \neq n' \\ 1 & \text{si } n = n' \end{cases}$$

$$\frac{1}{T} \int_0^T \cos\left(2n\pi \frac{s}{T}\right) \sin\left(2n'\pi \frac{s}{T}\right) ds = 0$$

$$\frac{1}{T} \int_0^T e^{+i2n\pi \frac{s}{T}} e^{-i2n'\pi \frac{s}{T}} ds = 0 \quad \text{si } n \neq n'$$

⑥

Question : quelle est la meilleure façon d'approcher une fonction <sup>(10)</sup> périodique par des sinusoides de fréquence entre 0 et N

ie si  $f$  est  $2\pi$ -périodique, quelle est la meilleure fonction  $f_N$  ?

$$f(t) = \sum_{k=-N}^N c_k e^{ikt}$$

$$= \frac{a_0}{2} + \sum_{k=1}^N a_k \cos(kt) + b_k \sin(kt)$$

Exercice : donner les équations liant  $c_k, c_{-k}$  et  $(a_k, b_k)$

Pourquoi la notion de meilleure est ambiguë : que cherche-t-on à rendre petit ?

Comment quantifier l'écart entre  $f$  et  $f_N$  ?

Ecart max  $\Sigma_{\infty}(f, f_N) = \|f - f_N\|_{\infty} = \sup_{[0, T]} |f(t) - f_N(t)|$

Ecart  $L^1$  :  $\Sigma_1(f, f_N) = \|f - f_N\|_1 = \int_0^T |f(t) - f_N(t)| dt$

Ecart  $L^2$  :  $\Sigma_2(f, f_N) = \|f - f_N\|_2 = \sqrt{\int_0^T |f(t) - f_N(t)|^2 dt}$

⑦

Avantage de  $\tau_c$  : calcul de  $\varepsilon_2^2$

$$\frac{1}{2\pi} \int_0^{2\pi} \left| f(t) - \sum_{-N}^N \alpha_k e^{ikt} \right|^2 dt$$

$$= \frac{1}{2\pi} \int_0^{2\pi} \left( f(t) - \sum_{-N}^N \alpha_k e^{ikt} \right) \overline{\left( f(t) - \sum_{-N}^N \alpha_k e^{ikt} \right)} dt$$

$$= \frac{1}{2\pi} \int_0^{2\pi} f(t) \overline{f(t)} dt - \sum_{-N}^N \alpha_k \frac{1}{2\pi} \int_0^{2\pi} f(t) e^{-ikt} dt - \sum_{-N}^N \overline{\alpha_k} \frac{1}{2\pi} \int_0^{2\pi} f(t) e^{ikt} dt + \sum_{k, k'} \overline{\alpha_k} \alpha_{k'} \int_0^{2\pi} e^{-ikt} e^{ik't} dt$$

On note  $c_k(f) = \frac{1}{2\pi} \int_0^{2\pi} f(t) e^{-ikt} dt$

$$\varepsilon_2^2 \left( f, \sum_{-N}^N \alpha_k e^{ikt} \right)$$

$$= \frac{1}{2\pi} \int_0^{2\pi} |f(t)|^2 dt$$

$$- \sum_{-N}^N \alpha_k \overline{c_k(f)} + \overline{\alpha_k} c_k(f) + c_k \overline{\alpha_k}$$

$$= \frac{1}{2\pi} \int_0^{2\pi} |f(t)|^2 dt - \sum_{-N}^N c_k(f) \overline{\alpha_k} + \sum_{-N}^N \overline{\alpha_k} c_k(f)$$

$$+ \sum_{-N}^N (\alpha_k - c_k) (\overline{\alpha_k} - \overline{c_k(f)})$$

$$= \frac{1}{2\pi} \int_0^{2\pi} |f(t)|^2 dt - \sum_{-N}^N |c_k(f)|^2 \rightarrow \text{ind de } \alpha$$

$$+ \sum_{-N}^N |\alpha_k - c_k(f)|^2 \rightarrow \geq 0 \text{ssi } \alpha_k = c_k$$

⑧

En quoi c'est une projection ?

$$f_N(t) = \sum_{-N}^{+N} c_k(f) e^{ik t}$$

$$g_N = \sum_{-N}^{+N} c_k(g) e^{ik t}$$

$$\langle f - f_N, g_N \rangle$$

$$= \sum_{-N}^{+N} \frac{1}{T} \int_0^T \left( \overline{f(s)} - \sum_{-N}^{+N} \overline{c_k} e^{-ik's} \right) \sum_{-N}^{+N} c_k e^{ik's} ds$$

$$= \sum_{-N}^{+N} \frac{1}{T} \int_0^T \overline{f(s)} e^{ik's} c_k(g) ds - \sum_{-N}^{+N} \overline{c_k(f)} c_k(g) e^{i(k-k)s} ds$$

$$= \sum_{-N}^{+N} \overline{c_k(f)} c_k(g) - \overline{c_k(f)} c_k(g)$$

$$= 0 !$$

9

### ③ Adaptation de la base aux données : ACP

ACP : Analyse en Composantes Prin cipales (PCA)

Question : On suppose qu'on a des données  $x_j^i$  ( $j$  indice d'individus)

en dimension "grande"  
 $x_j^i = (x_i^j)_{i=1, \dots, N \gg 1}$ .

Pour simplifier, on suppose qu'on a déjà centré les données ie  
 $\sum_j x_j^i = 0 \quad \forall i$

On voudrait représenter les données en 2D en gardant de la richesse.

Dispersion des données (variances)

$$\sum_j \sum_i (x_j^i)^2$$

Changement de base orthogonale

Pour le nouveau base  $\begin{pmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \dots \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 1 \end{pmatrix}$

⑩ Produit scalaire  $\langle Y, Y' \rangle = \sum_{i=1}^n Y_i \cdot Y'_i$

$$Y \perp Y' \quad \sum_{i=1}^n Y_i Y'_i = 0$$



$$\langle \vec{e}_i, \vec{e}_j \rangle = \begin{cases} 0 & \text{si } i \neq j \\ 1 & \text{si } i = j \end{cases}$$

$\vec{u}_1, \dots, \vec{u}_n$  est une base orthogonale

$$\text{si } \langle \vec{u}_i, \vec{u}_j \rangle = \begin{cases} 0 & \text{si } i \neq j \\ 1 & \text{si } i = j \end{cases}$$

Affirmation:  $X^j = \sum X_i^j \vec{e}_i$

$$= \sum \langle X^j, \vec{u}_i \rangle \vec{u}_i$$



Propriété:

$$\sum_{i,j} (X_i^j)^2 = \sum \langle X^j, X^j \rangle$$

$$= \sum_{j \neq i} \sum_i (X_i^j)^2$$

$$= \sum_j \sum_i \langle X^j, \vec{u}_i \rangle^2$$

①

Projection des  $X^j$  sur  $\vec{e}_1, \vec{e}_2$

$$\begin{pmatrix} X_1^j \\ X_2^j \\ 0 \end{pmatrix}$$

on garde la proportion

$$\frac{\sum_{i,j} (X_1^j)^2 + (X_2^j)^2}{\sum_{i,j} (X_i^j)^2}$$

Projection des  $X^j$  sur  $\vec{v}_1, \vec{v}_2$

$$\frac{\sum_{i,j} \langle X^j, \vec{v}_1 \rangle^2 + \langle X^j, \vec{v}_2 \rangle^2}{\sum_{i,j} (X_i^j)^2}$$

même

Peut on maximiser  $\sum_j \langle X^j, \vec{v}_1 \rangle^2 + \langle X^j, \vec{v}_2 \rangle^2$  ?

Spécial (oui)

Choix du premier vecteur  
(un plan est)

⑫

## II Mini introduction aux méthodes numériques

Comprendre le principe avec une fausse méthode

⑬

14

15